

自适应的粒子群优化-支持向量机动力电池自放电诊断

刘成豪^{1,2}, 张宇豪², 程端前², 杨飞², 付琰²

(1. 重庆大学 大数据与软件学院, 重庆 400044; 2. 中国汽车工程研究院股份有限公司, 重庆 401122)

摘要: 提出了一种基于单体电池自适应电压阈值和粒子群优化-支持向量机 (PSO-SVM) 的动力电池自放电故障诊断方法。主要关注动力电池电压信号, 结合箱型图法和专家审核, 完成自放电故障的样本标记, 再通过滑动窗口法提取时域和频域上的 16 种特征, 使用主成分分析法对电压特征进一步降维, 得到累计方差贡献度为 95% 的前 5 项主成分作为 PSO-SVM 模型的输入。该方法旨在提高电池自放电故障的识别精度, 最终结果表明, 提出的方法具有较高的识别准确率, 可靠性强, 在实际的电动汽车应用场景中有一定的前景和价值, 可为电动汽车安全性能的提升提供理论支撑。

关键词: 动力电池; 电压信号; 自放电; 支持向量机; 主成分分析

中图分类号: TN911; U469 文献标志码: A DOI: 10.3969/j.issn.2095-1469.2025.02.03

Adaptive Particle Swarm Optimization-Support Vector Machine for Self-Discharge Diagnosis of Lithium-Ion Batteries

LIU Chenghao^{1,2}, ZHANG Yuhao², CHENG Duanqian², YANG Fei², FU Yan²

(1. School of Big Data and Software Engineering, Chongqing University Chongqing 400044, China;
2. China Automotive Engineering Research Institute Co., Ltd., Chongqing 401122, China)

Abstract: Lithium-ion power batteries are currently the most widely used energy storage devices in electric vehicles. Rapid and accurate battery fault diagnosis is crucial for ensuring safe vehicle operation. This paper proposes a method for diagnosing self-discharge faults in power batteries based on adaptive voltage thresholds for individual cells and Particle Swarm Optimization-Support Vector Machine (PSO-SVM). This study focuses on the voltage signals of power batteries, and combines the boxplot method with expert review to label self-discharge fault samples. A sliding window method is used to extract 16 features from both the time and frequency domains. To further reduce the dimensionality of voltage features, principal component analysis is applied, selecting the top five principal components with a 95% cumulative variance contribution as inputs for the PSO-SVM model. This method aims to improve the accuracy of self-discharge fault detection in batteries. The results show that the proposed method achieves high detection accuracy, strong reliability, and promising potential for practical applications in electric vehicles. Additionally, it provides theoretical support for enhancing the safety performance of electric vehicles.

Keywords: power battery; voltage signal; self-discharge; support vector machine; principal component analysis

收稿日期: 2024-03-11 改稿日期: 2024-04-19 网络首发日期: 2024-06-13

基金项目: 国家重点研发计划 (2022YFE0102700); 大数据驱动的纯电动汽车运行安全性和经济性研究及测评技术开发

参考文献引用格式:

刘成豪, 张宇豪, 程端前, 等. 自适应的粒子群优化-支持向量机动力电池自放电诊断[J]. 汽车工程学报, 2025, 15(2): 147-154.

LIU Chenghao, ZHANG Yuhao, CHENG Duanqian, et al. Adaptive Particle Swarm Optimization-Support Vector Machine for Self-Discharge Diagnosis of Lithium-Ion Batteries[J]. Chinese Journal of Automotive Engineering, 2025, 15(2): 147-154. (in Chinese)



电动汽车作为解决能源和环境危机的有效方法之一,受到了全球各个国家的高度重视和大力支持。锂离子动力电池因具有高能量密度、高功率密度和长寿命等固有优势,作为电动汽车的储能装置得到了广泛的应用^[1]。然而,近年来的多起动力电池热失控事故对人们的驾驶安全造成了严重的威胁^[2],极大地限制了电动汽车的普及^[3]。根据 195 万辆电动汽车的统计数据,52% 的故障是由车载锂离子电池造成的^[4]。因此,如何实时准确地诊断电池系统故障,对于提高锂离子动力电池的安全性,推动电动汽车的快速普及至关重要。

电池的故障通常会体现在电压和电流上,例如电流波动和电压突然或持续的变化,意味着电池可能发生了某种故障,包括短路、连接异常或过放电等^[5-6]。因此,针对电池电压异常变化的实时检测可以提前定位故障发生的位置和时间以避免事故发生。然而,由于锂离子电池的电压信号具有时变特性、非线性和不一致性等特点,要挖掘出电压信号中隐藏的异常特征具有较高的挑战性^[7-9]。

现有文献已经提出了大量的故障诊断方法,通常分为两类:基于阈值的方法和基于模型的方法。

基于阈值的方法的主要诊断思想是将收集到的电池电流或电压数据与预先设置的故障判断阈值进行比较^[10]。目前多数电池管理系统都采用了这种方法^[11-12],它的优势在于简单易行。DUAN Bin 等^[13]基于信息熵计算所选指标的标准差,将其设置为阈值以评估单体电池的不一致性。实际上,基于阈值的方法不能预测电池故障的发生,并且如何选择合适的阈值是一个重要的挑战,如果阈值过高,故障诊断的灵敏度会过低,漏报率升高,相反,如果阈值太低,则会导致高频率的误报。但是电池电压信号具有非线性特征,线性阈值通常难以将异常区分开,基于阈值的方法对电池异常检测存在先天性的缺陷。

基于模型的方法主要考虑了正常或故障条件下电池状态的变化,通过建立电池的数学模型以获得

表征电池故障的参数。SIDHU 等^[14]提出了一种基于非线性模型和扩展卡尔曼滤波的故障诊断方法,通过估计模型的电池电压和端点电压之间的残差信号来检测电池故障。OUYANG Minggao 等^[15]提出了一种用于检测锂离子电池内部短路故障的平均差电池模型,该模型通过比较电池间电压和内部电阻之间的差异来确定故障信息。LIU Zhengtong 等^[16]使用自适应扩展卡尔曼滤波器来估计每个单体电池的状态,并将估计的输出电压与真实测量的电压进行比较生成残差,最终评估残差以确定电池故障。GAO Wenkai 等^[17]提出了一种使用均值差模型的电池组短路诊断方法,通过 SOC 差值和电阻阈值识别存在短路故障的单体电池。可以看出,基于模型的方法泛化性能较差,仅适用于特定故障,因为需要大量的前期工作来针对不同的故障进行测试和建模,所以存在复杂且鲁棒性差等问题。

近年来,大数据科学的发展为上述问题提供了新的解决思路^[18]。基于数据驱动的方法通过从电动汽车历史运行数据中提取故障敏感特征以建立与电池故障之间的非线性关系,这种方法避免了考虑电池本身的故障原理,可以高效地实现电池故障检测与识别。WANG Jia 等^[19]提出了一种基于改进径向基函数神经网络的电动汽车动力电池故障诊断方法,该方法分别使用广义回归神经网络和概率神经网络对锂离子电池包系统进行故障识别。YAO Lei 等^[20]提出了一种基于小波神经网络算法的电池故障检测方法,以提取电压数据的特征参数,如电压差、协方差和方差,并使用神经网络识别电池的故障状态。XIA Bing 等^[21]提出了一种基于相关性的电池短路故障诊断方法,可以根据每两个单体电池电压的相关系数识别异常电压变化。但是基于数据驱动的方法高度依赖于模型训练的大量样本数据,以建立数据与电池故障之间的潜在关系。事实上,用于模型训练的故障样本数据越准确,模型的诊断效果越好,这强调了样本标签的重要性,当前大多数诊断方法都是基于实验室数据,人为地制造

电池故障，很少在电动汽车实际运行中进行测试。而在实际运行中，获取故障样本标签是一项困难的工作，因为故障发生的时间和位置难以确定。

为了实现实际的电池故障检测，本研究提出了一种阈值与数据驱动相结合的动力电池故障检测方法，并基于新能源汽车国家大数据联盟西南分中心平台的电动汽车历史运行数据库进行了相应的验证。本文的主要贡献体现在以下3个方面。

1) 提出了一种基于自适应阈值和机器学习数据驱动的电池故障诊断方法，其中第1层自适应单体电池电压差阈值为后续机器学习模型提供了准确的故障标签样本数据，从而显著提高了故障诊断的可靠性和准确性。

2) 在时域和频域对电池电压信号提取到多种特征，从多维度挖掘电压信号中存在的潜在故障，然后使用主成分分析法对提取的特征进行降维，累计方差贡献率为95%的主成分作为机器学习模型的输入，从而降低计算成本。

3) 支持向量机模型用于完成故障诊断，并引入粒子群搜索算法优化支持向量机模型的惩罚参数和核函数带宽，最终基于电压信号实现准确实时的电池故障诊断。

1 数据来源

中国汽车工程研究院股份有限公司与新能源汽车国家大数据联盟合作成立“新能源汽车国家大数据联盟西南分中心”（简称：西南分中心）。平台使用Hadoop架构来确保数据收集和存储的可靠性，现已接入新能源汽车89万辆。平台遵循《电动汽车远程服务与管理系统技术规范》（GB/T 32960—2016），按照0.1 Hz的采样频率收集共41项数据内容，主要包括车速、充电状态、累计里程、SOC、电池系统总电压、单体电池电压、电流和探针温度等。本文研究的实车运行单体电池电压数据均来源于平台数据库。

2 基于自适应阈值的故障定位

2.1 故障类型

本研究主要针对电动汽车动力电池的自放电故障。电池的自放电故障往往持续存在，引起电芯间SOC差异逐渐增大，导致电池系统实际容量降低，SOC估算不准，限制电池的功率性能，引起电池超边界使用，严重时会引起电池内短路，导致电池快速升温，内部材料发生链式反应持续放热，导致电池热失控，进一步引起热扩散，引发电池包及车辆起火燃烧。

2.2 数据预处理

从西南分中心平台上下载28台新能源汽车历史运行数据，其中包含14台正常车数据和14台故障车数据，每台车的总运行里程都超过50 000 km。从中选取数据采集时间、总电压、总电流、单体电池总数、单体电池电压值列表、单体电池电压最高值、单体电池电压最低值和充电状态共8个类别数据。然后对上述数据进行清洗，清洗过程参考曾建邦等^[22]提出的方法：

- 1) 剔除数据列表中存在缺失值和无效值的行；
- 2) 剔除单体电池最低电压小于2.0和单体电池最高电压大于5.0的数据；
- 3) 剔除SOC小于10和大于80的行；
- 4) 筛选充电状态为静置充电的数据。

对于清洗后的数据，将单体电池电压值列表按单体电池编号分开，得到原始电压数据矩阵：

$$U = \{u_1^u, u_2^u, u_3^u, \dots, u_k^u\} \quad (1)$$

式中： k 为单体电池编号； u_k^u 为单体电池电压序列。

考虑电池发生自放电时，电压会表现出一定程度的波动，因此，对于每个单体电池电压序列 u_k ，计算到对应的电压中位数 x_k ，进一步求得 u_k 每个采样点与中位数 x_k 之间的差值，得到中位数差值矩阵 $U' = \{u_1', u_2', u_3', \dots, u_k'\}$ ，以表示该单体电池的电压信号相较于稳定电压的波动幅度。然后对每个单体电池电压的中位数差值序列 u_k' ，使用窗长为300的滑动窗口计算均值差分以平滑电压数据，最终得到原始电压的特征矩阵 $U_f = \{u_1, u_2, u_3, \dots, u_k\}$ 。

2.3 故障车辆阈值确定方法

为了确定自放电故障初步诊断的阈值,本文采用了箱型图法,该方法是一种非参数的异常值检测方法,无需符合正态分布,并且不受异常值的影响,鲁棒性较强。首先对于特征矩阵 U_f , 得到每个单体电池的第一四分位数 Q_1 和第三四分位数 Q_3 , 进一步得到四分位差:

$$IQR = Q_3 - Q_1,$$

$$Q_1 - m \times IQR \leq x \leq Q_3 + m \times IQR. \quad (2)$$

其中,当 $m = 3$ 时,采样点 x 的正常范围是满足条件 $[Q_1 - m \times IQR, Q_3 + m \times IQR]$ 以内,超出此范围被认定为异常值。由于有 k 个单体电池,因此,对应的故障诊断阈值也有 k 个。而且由于选取的故障诊断阈值是基于单体电池数据的,所以实现

每一辆车都有针对该车的特定电压阈值,即自适应阈值。这也体现了该自放电故障诊断方法的鲁棒性。

2.4 故障定位结果

根据 2.2 节和 2.3 节介绍的方法,对西南分中心平台导出的 14 辆故障车进行初步的自放电故障定位,两名具有中级以上职称的电池专家对故障输出结果进行了重复审查。最终确定了其中的 10 辆车真实存在自放电故障,某辆车的故障报警可视化如图 1 所示,纵坐标代表特征值大小。分析可得,第 64 号单体电池在 2021 年 1 月 8 日 07:51:12 到 2021 年 3 月 19 日 18:08:34 期间有持续下降趋势,当特征值低于单体电池预先设定的阈值之后即判定为存在自放电故障,图 1 中的黑线表示自适应的阈值。




图 1 自放电故障阈值

3 基于 PSO-SVM 的自放电故障诊断

3.1 特征提取

文章的第 3 部分已经确定了自放电故障发生的位置和时间,但在自放电故障初期,特征值在判定阈值周围波动,导致了初期的故障标签存在一定的稀疏性。因此,规定连续 5 min,即 30 个采样点都被判定为故障,则认为是稳定的自放电故障。

对于稳定的自放电故障的原始电压数据,采用滑动窗口法,选取窗长为 300,按照 50% 的重复率从左至右地将其分割,得到长度 $n = 300$ 的原始电压序列 $F(n)$,对 $F(n)$ 进行快速傅里叶变换 (FFT),可以得到其在频域上的频谱函数^[23]:

$$f_{\text{FFT}}(s) = \begin{cases} \sum_{n=0}^{N-1} F(n)W_N^{kn}, & 0 \leq k \leq N-1, \\ 0, & \text{others.} \end{cases} \quad (3)$$

进一步对 $F(n)$ 提取时域和频域上的共 16 个特征,时域:均值、方差、峰度、峭度、2 阶自相关系数、信号总能量、斜率、峰峰距离、绝对值平均偏差、均方根值和均值绝对值差分;频域:频谱距离、最大功率谱密度、功率谱密度带宽、频谱振幅下降幅度、谱熵。

对 10 辆自放电故障车执行上述对应的操作,最终得到 956 个自放电故障样本。对于 14 辆正常车,为了在降低样本数量的同时又尽可能地收集到采集周期内数据包含的所有信息,将每个单体电池的电压信号 u_k^n 均分为 10 段,在每段序列内随机截取 300 个连续的采样点,每个单体电池共得到 10 段长为 300 的电压子序列,然后分别对子序列提取到上述的 16 种特征,最终得到 14 020 个正常样本。在得到所有样本后,对每种特征进行归一化处理以消除量纲影响。

3.2 基于PCA的数据降维

在提取到的16种时域和频域特征中,可能存在某些相关变量,造成特征冗余。因此,使用主成分分析法,将原有的多个维度的相关变量综合为一个变量作为代表,它的目标是通过线性投影,将高维数据映射到低维空间中,并找到在所投影维度上数据的方差贡献率最大,以此降低数据维度,同时不会过多地丢失原始数据所包含的信息。

对于归一化后的样本集, KMO度量指数大于0.9, Bartlett球形度检验中显著性 $p < 0.01$,表明各维度的电压特征指标之间具有较高的相似性,可以通过主成分分析进一步降维。各主成分的累计方差贡献度曲线如图2所示,其中,前5项主成分累计方差贡献度超过了95%,则选择前5项主成分作为综合变量进行后续分析,即均值、方差、峰度、峭度、频谱距离。




图2 主成分累计方法贡献度曲线

3.3 识别模型构建与优化

本研究选择支持向量机来构建动力电池自放电故障识别模型,在先前的研究中已经证明了SVM模型的可行性^[24-26]。记动力电池状态样本集为 $\{x_i, y_i, i=1, 2, \dots, I\}, y_i \in \{0, 1\}, I=1, 2, \dots, 2022$,分别对应正常状态和故障状态,求解支持向量机最优分离超平面转化为了求解如下凸二次规划问题:

$$\begin{aligned} \min_{\omega, b} & \frac{1}{2} \|\omega\|^2, \\ \text{s.t.} & y_i(\omega^T \times x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, I. \end{aligned} \quad (4)$$

式中: ω 为 I 维权值向量; b 为常数偏置。

由于数据标签可能存在线性不可分割的情况,会影响模型寻找最优分离超平面。因此,引入松弛变量 $\zeta_i \geq 0$, 同时,对每个松弛变量 ζ_i , 支付一个代价 ζ_i 。于是当前模型的学习问题转化为如下凸二次规划问题:

$$\begin{aligned} \min_{\omega, b, \zeta} & \frac{1}{2} \|\omega\|^2 + c \times \sum_{i=1}^I \zeta_i, \\ \text{s.t.} & y_i(\omega^T \times x_i + b) \geq 1 - \zeta_i, \quad \zeta_i \geq 0, \\ & i = 1, 2, \dots, I. \end{aligned} \quad (5)$$

式中: $c > 0$ 称为惩罚参数,为用户选定的正参数。进一步对每个不等式约束引入拉格朗日乘子向量 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_I)^T$, 定义拉格朗日函数:

$$\begin{aligned} L(\omega, b, \zeta, \alpha, \mu) &= \frac{1}{2} \|\omega\|^2 + c \times \sum_{i=1}^I \zeta_i - \\ & \sum_{i=1}^I \alpha_i (y_i(\omega^T \times x_i + b) - 1 + \zeta_i) - \sum_{i=1}^I \mu_i \zeta_i. \end{aligned} \quad (6)$$

式中: $\alpha_i \geq 0, \mu_i \geq 0$ 。

得到此问题的对偶形式为:

$$\begin{aligned} \max_{\alpha} & \frac{1}{2} \sum_{i=1}^I \sum_{j=1}^I \alpha_i \alpha_j y_i y_j (x_i \times x_j) + \sum_{i=1}^I \alpha_i, \\ \text{s.t.} & \sum_{i=1}^I \alpha_i y_i = 0, \quad 0 < \alpha_i < c. \end{aligned} \quad (7)$$

计算可得对偶问题的最优解 $\alpha_i^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_I^*)^T$, 则原始问题的最优解 ω^* 和 b^* 可表示为:

$$\omega^* = \sum_{i=1}^I \alpha_i^* y_i x_i. \quad (8)$$

$$b^* = y_i - \sum_{i=1}^I y_i \alpha_i^* (x_i \times x_j). \quad (9)$$

由上式可得分离超平面和分类决策函数:

$$\sum_{i=1}^I y_i \alpha_i^* (x \times x_i) + b^* = 0. \quad (10)$$

$$f(x) = \text{sign} \left(\sum_{i=1}^I y_i \alpha_i^* (x \times x_i) + b^* \right). \quad (11)$$

SVM 可以通过应用核函数将原始空间中的线性不可分割的数据映射到另一个高维特征空间 \mathcal{H} , 以求得最优分离超平面。基于径向基核函数的支持向量机模型分类决策函数如式(12)所示,它对复杂数据有较好的抗干扰能力^[27]:

$$K(x, x_i) = \exp \left(-\frac{\|x - x_i\|^2}{2\sigma^2} \right). \quad (12)$$

式中: $\frac{1}{2\sigma^2} > 0$ 为核函数带宽,用 g 表示。

将式 (12) 代入式 (11), 可得到此情形下的分类决策函数为:

$$f(x) = \text{sign}\left(\sum_{i=1}^l y_i \alpha_i^* \exp(-g\|x - x_i\|^2) + b^*\right) \quad (13)$$

式中: x , x_i , α_i^* , b^* 为模型优化求解得到的参数。

同时, 在建模过程中引入粒子群寻优算法, 对径向基核函数的核函数带宽 g 和惩罚参数 c 进行优化, 设定初始粒子种群数量为 10, 优化迭代次数为 100 次。

将一组未知状态的电池样本 x_i 代入分类决策函数中, $f(x_i)$ 为输出结果, 若 $f(x_i) = 0$, 则判定 x_i 为正常状态, 若 $f(x_i) = 1$, 则认为 x_i 存在自放电故障。

3.4 模型识别结果

将经过主成分分析后的前 5 个主成分作为 PSO-SVM 模型的输入, 以 4:1 的比例随机抽取被试样本作为训练集和测试集, 重复 50 次模型的训练和测试过程, 将得到的模型识别准确率取平均值, 模型对测试集的最终识别效果如图 3 所示。将 PSO-SVM 模型与常用的 5 种机器学习模型的识别准确率进行对比, 结果见表 1, 可以看出 PSO-SVM 模型对电动汽车动力电池自放电故障的识别准确率达到最高, 为 98.26%, 说明本文提出的方法精准性较好。

4 结论

为了提高电动汽车动力电池的安全性能, 本文提出了一种基于自适应阈值和 PSO-SVM 的自放电故障诊断方法, 该方法可以实时准确地定位到具有潜在自放电隐患的单体电池, 在故障发生早期完成诊断, 避免安全性能的进一步恶化, 从而防止热失控事件的发生。

首先对单体电池电压序列进行初步的特征提

真实值	正样本	2759	49
	负样本	3	185
		正样本	负样本
		预测值	

图 3 混淆矩阵

表 1 机器学习模型的识别准确率 %

模型	随机森林	Bagging	AdaBoost	决策树	逻辑回归	PSO-SVM
准确率	92.55	80.60	93.53	91.04	72.64	98.26

取, 使用箱型图法设定单体电池自适应的故障诊断阈值, 结合人工审核的方法标记自放电故障发生的位置和时刻, 作为后续识别模型的故障标签。然后运用滑动窗口法提取正常和异常的电压样本, 对每个样本可以提取时域和频域上的 16 种特征, 采用主成分分析法进一步降维, 得到累计方差贡献度为 95% 的 5 项主成分作为 PSO-SVM 模型的输入, 最终结果表明, 该模型具有较高的识别准确率, 可用于电动汽车动力电池自放电故障监测, 为电动汽车驾驶安全性能提升提供理论支撑。

在未来的研究中, 可考虑采用无监督的学习方法, 利用正常样本训练识别模型, 避免标签不准确带来的影响。此外, 本研究只考虑了在电池充电状态下的自放电现象, 事实上在车辆运行时, 电压信号中也可能包含某些关键的自放电信息, 因此, 下一步将尝试结合电动汽车的场景工况, 充分挖掘电池全生命周期数据, 尽可能准确地识别自放电故障。

参考文献 (References)

- [1] WANG Chaoyang, ZHANG Guangsheng, GE Shanhai, et al. Lithium-Ion Battery Structure That Self-Heats at Low Temperatures[J]. Nature, 2016, 529(7587): 515-518.
- [2] WANG Li, XIE Leqiong, TIAN Guangyu, et al. Safety Accidents of Li-Ion Batteries: Reliability Issues or Safety Issues[J]. Energy Storage Science and Technology, 2021, 10(1): 1-6.
- [3] MA Mina, LI Xiaoyu, GAO Wei, et al. Multi-Fault

- Diagnosis for Series-Connected Lithium-Ion Battery Pack with Reconstruction-Based Contribution Based on Parallel PCA-KPCA [J]. *Applied Energy*, 2022, 324: 119678.1-119678.12.
- [4] SHANG Yunlong, LU Gaopeng, KANG Yongzhe, et al. A Multi-Fault Diagnosis Method Based on Modified Sample Entropy for Lithium-Ion Battery Strings [J]. *Journal of Power Sources*, 2020, 446: 227275.1-227275.12.
- [5] FENG Xuning, WENG Caihao, OUYANG Minggao, et al. Online Internal Short Circuit Detection for a Large Format Lithium Ion Battery [J]. *Applied Energy*, 2016, 161: 168-180.
- [6] FENG Xuning, HE Xiangming, LU Languang, et al. Analysis on the Fault Features for Internal Short Circuit Detection Using an Electrochemical-Thermal Coupled Model [J]. *Journal of the Electrochemical Society*, 2018, 165(2): A155-A167.
- [7] HANNAN M A, LIPU M S H, HUSSAIN A, et al. A Review of Lithium-Ion Battery State of Charge Estimation and Management System in Electric Vehicle Applications: Challenges and Recommendations [J]. *Renewable and Sustainable Energy Reviews*, 2017, 78: 834-854.
- [8] XIONG Rui, YU Quanqing, SHEN Weixiang, et al. A Sensor Fault Diagnosis Method for a Lithium-Ion Battery Pack in Electric Vehicles [J]. *IEEE Transactions on Power Electronics*, 2019, 34(10): 9709-9718.
- [9] ZHANG Caiping, JIANG Yan, JIANG Jiuchun, et al. Study on Battery Pack Consistency Evolutions and Equilibrium Diagnosis for Serial-Connected Lithium-Ion Batteries [J]. *Applied Energy*, 2017, 207: 510-519.
- [10] EI MEJDOUBI A, CHAOUI H, GUALOUS H, et al. Lithium-Ion Batteries Health Prognosis Considering Aging Conditions [J]. *IEEE Transactions on Power Electronics*, 2018, 34(7): 6834-6844.
- [11] ZHAO Rui, LIU Jie, GU Junjie. Simulation and Experimental Study on Lithium Ion Battery Short Circuit [J]. *Applied Energy*, 2016, 173: 29-39.
- [12] XIA Bing, CHEN Zheng, MI C, et al. External Short Circuit Fault Diagnosis for Lithium-Ion Batteries [C]// 2014 IEEE Transportation Electrification Conference and Expo (ITEC), June 15-18, 2014, Dearborn, MI, USA. Piscataway NJ: IEEE, c2014: 1-7.
- [13] DUAN Bin, LI Zeyuan, GU Pingwei, et al. Evaluation of Battery Inconsistency Based on Information Entropy [J]. *Journal of Energy Storage*, 2018, 16: 160-166.
- [14] SIDHU A, IZADIAN A, ANWAR S. Adaptive Nonlinear Model-Based Fault Diagnosis of Li-Ion Batteries [J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(2): 1002-1011.
- [15] OUYANG Minggao, ZHANG Mingxuan, FENG Xuning, et al. Internal Short Circuit Detection for Battery Pack Using Equivalent Parameter and Consistency Method [J]. *Journal of Power Sources*, 2015, 294: 272-283.
- [16] LIU Zhengtong, HE Hongwen. Sensor Fault Detection and Isolation for a Lithium-Ion Battery Pack in Electric Vehicles Using Adaptive Extended Kalman Filter [J]. *Applied Energy*, 2017, 185: 2033-2044.
- [17] GAO Wenkai, ZHENG Yuejiu, OUYANG Minggao, et al. Micro-Short-Circuit Diagnosis for Series-Connected Lithium-Ion Battery Packs Using Mean-Difference Model [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(3): 2132-2142.
- [18] OUYANG Minggao, ZHANG Mingxuan, FENG Xuning, et al. Internal Short Circuit Detection for Battery Pack Using Equivalent Parameter and Consistency Method [J]. *Journal of Power Sources*, 2015, 294: 272-283.
- [19] WANG Jia, ZHANG Shenglong, HU Xia. A Fault Diagnosis Method for Lithium-Ion Battery Packs Using Improved RBF Neural Network [J]. *Frontiers in Energy Research*, 2021, 9: 702139.1-702139.9.
- [20] YAO Lei, XIAO Yanqiu, GONG Xiaoyun, et al. A Novel Intelligent Method for Fault Diagnosis of Electric Vehicle Battery System Based on Wavelet Neural Network [J]. *Journal of Power Sources*, 2020, 453: 227870.1-227870.12.
- [21] XIA Bing, SHANG Yunlong, NGUYEN T, et al. A Correlation Based Fault Detection Method for Short Circuits in Battery Packs [J]. *Journal of Power Sources*, 2017, 337: 1-10.
- [22] 曾建邦, 张月娅, 张壮, 等. 基于动态k值K-means++聚类的电动汽车动力电池电压不一致故障识别方法 [J]. *中国科学: 技术科学*, 2023, 53(1): 28-40.
- ZENG Jianbang, ZHANG Yueya, ZHANG Zhuang, et al. Identification of Power Battery Voltage Inconsistency Faults in Electric Vehicles Based on K-Means++ Clustering with Dynamic k-Values [J]. *Scientia Sinica (Technologica)*, 2023, 53(1): 28-40. (in Chinese)
- [23] ZHANG Yuhao, GUO Hanying, ZHOU Yongjian, et al. Recognising Drivers' Mental Fatigue Based on EEG Multi-Dimensional Feature Selection and Fusion [J]. *Biomedical Signal Processing and Control*, 2023, 79: 975-987.

- [24] JEBELLI H, HWANG S J, LEE S H. EEG-Based Workers' Stress Recognition at Construction Sites [J]. *Automation in Construction*, 2018, 93: 315–324.
- [25] PAL N R, CHUANG C Y, JUNG T P, et al. EEG-Based Subject-and Session-Independent Drowsiness Detection: An Unsupervised Approach [J]. *EURASIP Journal on Advances in Signal Processing*, 2008, 20: 519480.1–519480.11.
- [26] JIAO Yingying, LU Baoliang. Detecting Driver Sleepiness from EEG Alpha Wave During Daytime Driving [C]//2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), Nov. 13–16, 2017, Kansas City, MO, USA. Piscataway NJ: IEEE, c2017: 728–731.
- [27] 郭孜政, 潘雨帆, 周宏宇, 等. 驾驶人对潜在危险性事件的心理预期识别研究 [J]. *中国公路学报*, 2020, 33(6): 119–128.
- GUO Zizheng, PAN Yufan, ZHOU Hongyu, et al. Estimation of the Drivers' Psychological Anticipation of Potentially Hazardous Events [J]. *China Journal of Highway and Transportation*, 2020, 33(6): 119–128. (in Chinese)

作者简介



刘成豪 (1996–), 男, 重庆永川人, 博士, 工程师, 主要研究方向为新能源汽车大数据安全预警。

E-mail: liuchenghao@caeri.com.cn

通信作者



程端前 (1983–), 男, 湖北咸宁人, 学士, 高级工程师, 主要研究方向为新能源汽车安全健康管理。

E-mail: chengduanqian@caeri.com.cn